



F3

**Fakulta elektrotechnická
Katedra kybernetiky**

Bakalářská práce

Detekce emocí z psaného textu

Klára Losenická

Květen 2024

Vedoucí práce: doc. Ing. Daniel Novák, Ph.D.

Studijní program: Otevřená informatika

Specializace: Základy umělé inteligence a počítačových věd

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Losenická** Jméno: **Klára** Osobní číslo: **503234**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra kybernetiky**
Studijní program: **Otevřená informatika**
Specializace: **Základy umělé inteligence a počítačových věd**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Detekce emocí z psaného textu

Název bakalářské práce anglicky:

Emotion Detection from Written Text

Pokyny pro vypracování:

- Získejte přehled o metodách rozpoznávání emocí v textu a prozkoumejte základní dostupné knihovny.
- Získejte přehled o datasetech, které se používají pro trénink modelů na detekci emocí textu. Vyhledejte a analyzujte české i anglické datasety.
- Implementujte kompletní procesní řetězec pomocí vybraných knihoven či modelů. Procesní řetězec by měl detekovat emoce v českém i anglickém textu.

Seznam doporučené literatury:

- [1] Guo, Jia. "Deep learning approach to text analysis for human emotion detection from big data" Journal of Intelligent Systems, vol. 31, no. 1, 2022
- [2] Shiqing Zhang, Yijiao Yang, Chen Chen, Xingnan Zhang, Qingming Leng, Xiaoming Zhao, Deep learning-based multimodal emotion recognition from audio, visual, and text modalities: A systematic review of recent advancements and future prospects, Expert Systems with Applications, Volume 237, 2024
- [3] Ghafoor, Y., Jinping, S., Calderon, F.H. et al. TERMS: textual emotion recognition in multidimensional space. Appl Intell 53, 2673–2693, 2023

Jméno a pracoviště vedoucí(ho) bakalářské práce:

doc. Ing. Daniel Novák, Ph.D. Analýza a interpretace biomedicínských dat FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) bakalářské práce:

Datum zadání bakalářské práce: **23.01.2024**

Termín odevzdání bakalářské práce: **24.05.2024**

Platnost zadání bakalářské práce: **21.09.2025**

doc. Ing. Daniel Novák, Ph.D.
podpis vedoucí(ho) práce

prof. Dr. Ing. Jan Kybic
podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Studentka bere na vědomí, že je povinna vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studentky

Poděkování / Prohlášení

Ráda bych poděkovala doc. Ing. Danielu Novákovi, Ph.D. za jeho vedení během mé bakalářské práce. Jeho odbornost a podpora byly nepostradatelné pro mé úspěchy. Děkuji rovněž mým kolegům Chengu Kangovi, MSc., Bc. Fabiánovi Bodnárovi, Bc. Štěpánovi Bořkovi, Ing. Patrikovi Jankuv, Ing. Jindřichovi Prokopovi, Bc. Petrovi Karlíkovi, Petrovi Stádníkovi a Varvare Shorině za jejich spolupráci a přínos k úspěšnému dokončení této práce.

Nakonec bych chtěla vyjádřit velké díky mým rodičům za jejich neustálou podporu během mého studia. Jsou mou nezbytnou oporou a jejich příklad mě neustále inspiruje.

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne 24. 5. 2024

.....

Abstrakt / Abstract

Tato bakalářská práce se zaměřuje na analýzu a implementaci metod pro detekci emocí z psaného textu. Emoce hrají zásadní roli v lidské komunikaci a jejich automatická detekce z textu může mít široké uplatnění v různých oblastech. Cílem této práce je provést komparativní analýzu různých modelů, včetně specializovaných a velkých jazykových modelů, a zhodnotit jejich výkonnost.

Práce poskytuje teoretický přehled emocí, včetně modelů Paula Ekmana a Jamese Russella. Popisuje různé modely pro detekci emocí, jako jsou AutoTrain, Emotion Detection by Lawal Alfeez, model od Andyho Luana, ChatGPT 3.5 turbo a Llama70D, a hodnotí jejich výkon na českých a anglických datasetech.

Výsledky ukazují, že velké jazykové modely, jako ChatGPT 3.5 turbo a Llama70D, dosahují vyšší přesnosti a spolehlivosti v detekci emocí než specializované modely. Budoucí výzkum by se mohl zaměřit na zdokonalení modelů, rozšíření datasetů a nové přístupy k anotaci emocí.

Klíčová slova: Detekce emocí, Velké jazykové modely, Analýza sentimentu, Zpracování přirozeného jazyka

This bachelor's thesis focuses on the analysis and implementation of methods for detecting emotions from written text. Emotions play a crucial role in human communication, and their automatic detection from text has wide applications in various fields. The aim of this study is to perform a comparative analysis of different models, including specialized and large language models, and evaluate their performance.

The thesis provides a theoretical overview of emotions, including the models of Paul Ekman and James Russell. It describes various models for emotion detection, such as AutoTrain, Emotion Detection by Lawal Alfeez, model by Andy Luan, ChatGPT 3.5 turbo, and Llama70D, and evaluates their performance on Czech and English datasets.

The results show that large language models like ChatGPT 3.5 turbo and Llama70D achieve higher accuracy and reliability in detecting emotions compared to specialized models. Future research could focus on improving models, expanding datasets, and exploring new approaches to emotion annotation.

Keywords: Emotion Detection, Large Language Models, Sentiment Analysis, Natural Language Processing

Obsah /

1 Úvod	1		
2 Emoce	2		
2.1 Vlastnosti emocí	2		
2.2 Sentiment	2		
2.3 Základní emoce podle P. Ekmana	2		
2.3.1 Hněv	3		
2.3.2 Překvapení	3		
2.3.3 Znechucení	3		
2.3.4 Nadšení	3		
2.3.5 Strach	3		
2.3.6 Smutek	3		
2.4 Circumplex model	4		
2.4.1 Definice	4		
2.4.2 Kvadranty circumplex	4		
3 Testované modely	6		
3.1 Úvod	6		
3.2 AutoTrain	6		
3.2.1 Trénování	6		
3.3 Emotion Detection by La- wal Alfeez	7		
3.3.1 DistilBERT	7		
3.3.2 BERT	7		
3.4 Emotion Detection by An- dy Luan	7		
3.4.1 Bloom	7		
3.5 ChatGPT 3.5 turbo	8		
3.6 Lama70D	8		
3.6.1 Groq	9		
4 Datové zdroje	10		
4.1 Český dataset	10		
4.2 Emotion Dataset for Emo- tion Recognition Tasks	11		
4.3 Dataset Emotion Detection from Text	11		
4.4 Dataset GoEmotions	12		
5 Testování a implementace	13		
5.1 Získávání dat	13		
5.1.1 HuggingFace	13		
5.1.2 ChatGPT	14		
5.1.3 Groq	15		
5.1.4 Získávání českých dat	16		
5.2 Použité metody testování	17		
6 Výsledky	19		
6.1 Matice záměn	19		
6.1.1 Porovnání výsledků českého datasetu	19		
6.1.2 Porovnání v rámci ka- tegorizace Circumplex	20		
6.1.3 Porovnání v rámci ka- tegorizace dle Ekmana	22		
6.1.4 Porovnání v rámci ka- tegorizace do sentimentů	23		
6.2 Porovnání kategorizačních metod	24		
6.3 Obecné výsledky	25		
7 Závěr	28		
Literatura	29		
A Zkratky a použité nástroje	31		
A.1 Zkratky	31		
A.2 Použité nástroje	31		

Tabulky / Obrázky

3.1	Výkon jazykového zpracování produktu Groq	9
4.1	Emoční rozdělení českého datasetu	10
4.2	Rozdělení datasetu emotion Dataset for Emotion Recognition Tasks	11
4.3	Rozdělení datasetu emotion Dataset for Emotion Recognition Tasks převedého na Ekman kategorie	11
4.4	Rozdělení emocí v datasetu Emotion Detection from Text ..	12
4.5	Rozdělení datasetu Emotion Detection from Text převedého na Ekman kategorie.....	12
6.1	Výsledky testů pro česká data ..	19
6.2	Výsledky testů pro všechny modely	25
6.3	Výsledky testů pro všechny modely	26
2.1	Vizualizace circumplex modelu ..	4
6.1	Matice záměn pro model Llama 70D, česká data	20
6.2	Matice záměn pro model ChatGPT 3.5 turbo, česká data	20
6.3	Matice záměn pro model Llama 70D, kategorizace: Circumplex.....	21
6.4	Matice záměn pro model ChatGPT 3.5 turbo, kategorizace: circumplex.....	21
6.5	Matice záměn pro model Andy Luan, kategorizace: Circumplex.....	21
6.6	Matice záměn pro model Rahul Mahalan, kategorizace: Circumplex	21
6.7	Matice záměn pro model Andy Luan, kategorizace: Ekman	22
6.8	Matice záměn pro model Rahul Mahalan, kategorizace: Ekman	22
6.9	Matice záměn pro model Llama 70D, kategorizace: Ekman ..	23
6.10	Matice záměn pro model ChatGPT 3.5 turbo, kategorizace: Ekman.....	23
6.11	Matice záměn pro model Andy Luan, kategorizace: sentiment	23
6.12	Matice záměn pro model Rahul Mahalan, kategorizace: sentiment	23
6.13	Matice záměn pro model Llama 70D, kategorizace: sentiment	24
6.14	Matice záměn pro model chatGPT 3.5 turbo, kategorizace: sentiment	24
6.15	Graf úspěšnosti v jednotlivých testech, kategorizace: Ekman	25

6.16	Graf úspěšnosti v jednotlivých testech, kategorizace: Circumplex	25
6.17	Graf úspěšnosti v jednotlivých testech na základních datech bez jakékoliv kategorizace	26

Kapitola 1

Úvod

V dnešní digitální éře, kde komunikace prostřednictvím textových zpráv a sociálních médií dominuje, se stále více stává důležitým rozpoznávání emocí v psaném textu. Emoce hrají klíčovou roli v lidské interakci a porozumění těmto emocím může mít široké uplatnění v mnoha oblastech, včetně zákaznické podpory, marketingu, a dokonce i v psychologii. Detekce emocí z textu se zaměřuje na analýzu psaného slova s cílem identifikovat a kategorizovat emoce vyjádřené autorem.

Cílem této bakalářské práce je prozkoumat různé metody a přístupy k detekci emocí v psaném textu. V práci se zaměříme na porovnání několika specializovaných modelů a velkých jazykových modelů, které jsou navrženy pro tento účel. Zvláštní pozornost bude věnována modelům, které využívají hlubokého učení a pokročilých technik zpracování přirozeného jazyka (NLP).

V první kapitole se zaměříme na teoretický základ emocí, jejich vlastnosti a různé modely jejich kategorizace, jako jsou základní emoce podle Paula Ekmana a circumplex model Jamese Russella. Následně se ve druhé kapitole podíváme na různé testované modely a popíšeme jejich architekturu a způsoby trénování. Ve třetí kapitole se budeme věnovat dostupným datasetům pro trénink a testování modelů, se zvláštním důrazem na české a anglické datasety.

Čtvrtá kapitola bude obsahovat implementaci a testování jednotlivých modelů, kde popíšu postupy a metody použité k evaluaci jejich výkonnosti. V páté kapitole se zaměříme na výsledky testování, které budou prezentovány pomocí grafů a matic záměn. Závěrem shrneme hlavní zjištění práce a navrhneme možné směry dalšího výzkumu v této oblasti.

Tato práce si klade za cíl nejen přispět k lepšímu porozumění metod detekce emocí z textu, ale také nabídnout praktické poznatky, které by mohly být využity v různých aplikacích a oborech.

Kapitola 2

Emoce

Slovník spisovného jazyka českého definuje emoce jako „*silný cit, citové vzrušení, často doprovázené fyziologickými změnami, změnami chování*“. Emoce jsou určovány sociokulturně, biologicky a psychologicky. Z toho důvodu se vědecká komunita pře nad definicí emocí. Psychologové se neustálili na obecné definici. William James navrhl, že tělesné změny přímo následují vnímání vzrušující skutečnosti a že náš pocit stejných změn, ke kterým dochází, je emoce. Walter B. Cannon poznamenal, že spodní část mozku, kterou neurovědci nazývají thalamus, řídí emoční zážitek.[1] Magda B. Arnold zdůraznil, že hodnocení vnějšího prostředí je přímou příčinou emocí.[2] Richard Lazarus vnímal emoce jako komplexní reakci a tvrdil, že žádnou emoci nelze určit jedinou složkou. [3] Neurovědci zkoumali fyziologickou stranu emocí. Přestože není tato oblast dostatečně prozkoumaná, zjistili, že se některé emoce pojí s amygdalou.[4]

2.1 Vlastnosti emocí

Momentálně se emoce zařazují do samostatného emočního systému, který se skládá ze 4 komponent:

- situace, které podněcují emoční reakci,
- vědomý prožitek,
- fyziologické vzrušení, který tělo vytváří autonomně,
- chování, které je emocí vyvoláno.

K pochopení emocí přispívá rovněž jejich role v regulaci chování. Komplexní porozumění emocí je v současné době spíše výjimečné, protože to zahrnuje pochopení několika vědních oborů [5].

2.2 Sentiment

Sentiment je afektivní hodnota nebo postoj, který mluvčí mají ve vztahu k určitému tématu, jako je například film nebo kamera. Tento sentiment má obvykle pevnou hodnotu (např. dobrý nebo špatný) a je vyjádřen v textu prostřednictvím slov nebo malých kombinací slov. V oblasti zpracování přirozeného jazyka se však často nediskutuje o tom, co sentiment nebo názor skutečně je, jak je vyjadřován v reálném jazyce, jak jsou tato vyjadřovací slova organizována v lexikonu a jak lze empiricky ověřit kognitivní tvrzení související s implementací NLP [6].

2.3 Základní emoce podle P. Ekmana

PH.D. Paul Ekman je jedním z nejcitovanějších psychologů 20. století. Proslavil se hlavně studiem emocí. Zaměřoval se na mimiku obličeje. Vyvinul tzv. mikrovýrazy obličeje. Ukázal, že mimika obličeje je univerzální. Jinými slovy, lidé ve Spojených státech

se tváří při smutku stejně jako domorodí obyvatelé Papua Nové Guineji, kteří nikdy neviděli televizní nebo filmové postavy, podle kterých by se mohli modelovat. Zjistil také, že vrozeně slepí jedinci mají také stejné výrazy obličeje, i když nikdy neviděli tváře jiných lidí. [7].

Identifikoval šest základních emocí jako hněv, překvapení, znechucení, nadšení, strach a smutek. Jeho pozdější výzkum ukazuje důkaz sedmé emoce, kterou je pohrdání[8]. V naší práci se budeme zabývat pouze základními šesti emocemi.

■ 2.3.1 Hněv

Hněv obsahuje jak zlost, tak zuřivost. Intenzita těchto stavů je různá: Můžeme cítit mírnou nebo silnou mrzutost, ale můžeme cítit pouze intenzivní zuřivost. Všechny stavy hněvu jsou spouštěny pocitem, že jsme blokováni v našem pokroku.

K hněvu patří dále mstivost, hořkost, argumentativnost, frustrace, podráždění, mrzutost a mnoho dalších pocitů. [9]

■ 2.3.2 Překvapení

Překvapení obsahuje jak údiv, tak vzrušení. Intenzita těchto stavů je různá: Můžeme cítit mírné nebo silné překvapení, ale můžeme cítit pouze intenzivní vzrušení. Všechny stavy překvapení jsou spouštěny neočekávanou událostí nebo informací.

Kromě toho k překvapení patří i ohromení, radostné šokování, nevědomost, zmatení, a další. [9]

■ 2.3.3 Znechucení

Znechucení zahrnuje jak neoblíbenost, tak pohrdání. Intenzita těchto pocitů se může lišit: můžeme pocíťovat mírnou nebo silnou neoblíbenost, ale pohrdání bývá vždy intenzivní. Všechny projevy odporu jsou vyvolány pocitem, že něco je jedovatého. Pohrdání, odvrát, odmítání, odpor nesnášenlivost, antipatie všechny patří k znechucení spolu s mnoha dalšími. [9]

■ 2.3.4 Nadšení

Nadšení obsahuje jak mír, tak extázi. Intenzita těchto stavů se liší: Můžeme cítit mírný nebo silný klid, ale můžeme cítit pouze intenzivní extázi. Všechny stavy prožitku jsou spouštěny pocitovým spojením nebo smyslovým potěšením. [9]

■ 2.3.5 Strach

Strach obsahuje úzkost i hrůzu. Intenzita těchto stavů je různá: Můžeme pocíťovat mírnou nebo silnou úzkost, ale můžeme cítit pouze intenzivní hrůzu. Všechny stavy strachu jsou spouštěny pocitem hrozby újmy.

Teror, hrůza, úzkost, panika, zoufalost a mnoho dalších patří do kategorie strachu. [9]

■ 2.3.6 Smutek

Smutek obsahuje jak zklamání, tak zoufalství. Intenzita těchto emocí se může lišit: Můžeme prožívat mírné nebo silné zklamání, ale zoufalství bývá vždy intenzivní. Všechny formy smutku jsou vyvolány pocitem ztráty.

Smutek je také velice obsáhlá kategorie, která obsahuje mnoho emocí například utrpení, žal, truchlení, zoufalství, beznaděj, rezignace, zmatenost, klid.[9]

2.4 Circumplex model

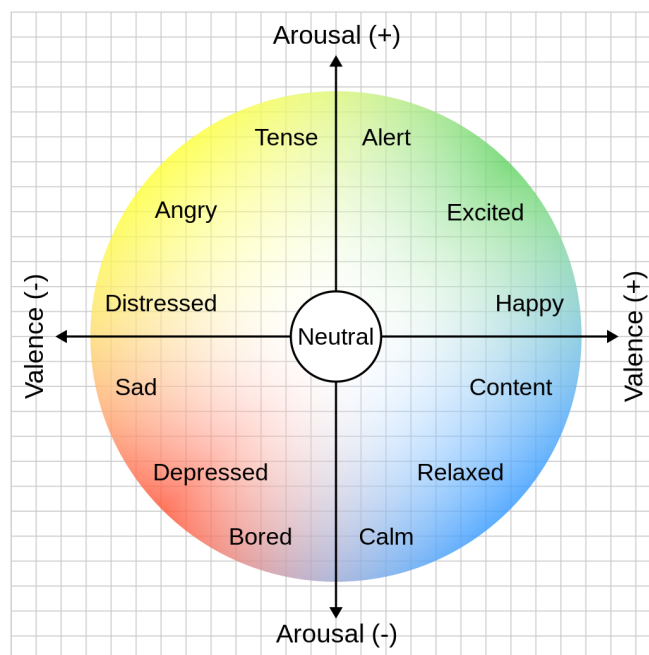
Circumplex model byl představen Jamesem Russelem v době, kdy byl obecně psychologi využíván model kategorií dle Paula Ekmana. Circumplex model měl vyřešit problémy pacientů zařadit emoci do určité kategorie.

Problém zařazovat emoce ukazuje na to, že emoce nejsou jen izolovaný jev, ale spíše, že je to několik překrývajících se zážitků. Podobně jako je spektrum barev, emocím také chybí přesné hranice, kde se střídají. Tudíž se logicky přešlo k více dimenzionálním modelům. [10]

2.4.1 Definice

Model Circumplex emocí je teoretický rámec, který organizuje emoce do kruhové struktury na základě dvou hlavních dimenzí: valence a arousal.

- Valence: Tato dimenze se týká positivity nebo negativity emoce. Emoce na pozitivním konci valenčního spektra jsou příjemné, zatímco ty na negativním konci jsou nepříjemné.
- Arousal: Tato dimenze odkazuje na úroveň fyziologické aktivity spojené s emocí. Emoce s vysokým arousal zahrnují intenzivní fyziologické reakce, jako je zvýšený srdeční tep a zvýšená bdělost, zatímco emoce s nízkým arousal jsou klidnější.



Obrázek 2.1. Ukázka vizualizace circumplex modelu [11] .

2.4.2 Kvadranty circumplex

Spojením těchto dvou dimenzí model Circumplex vytváří kruhovou reprezentaci emocí. Emoce jsou umístěny v kruhu na základě jejich valence (od pozitivní po negativní) a úrovně arousalu (od nízkého po vysokého). To vytváří kvadranty uvnitř kruhu, které představují různé typy emocí:

- Vysoký arousal, pozitivní valence: Emoce jako radost, vzrušení a extáze.
- Vysoký arousal, negativní valence: Emoce jako hněv, strach a úzkost.
- Nízký arousal, pozitivní valence: Emoce jako spokojenost, klid a relaxace.
- Nízký arousal, negativní valence: Emoce jako smutek, nudění a deprese.

Model naznačuje, že emoce v každém kvadrantu sdílejí určité charakteristiky a mohou mít podobné behaviorální, fyziologické a kognitivní vzory. Kromě toho model zdůrazňuje, jak mohou emoce variabilně kolísat ve své intenzitě a kvalitě, poskytující komplexní rámec pro porozumění a kategorizaci lidských emocionálních zkušeností.

Kapitola 3

Testované modely

3.1 Úvod

V začátcích projektu jsme hledali, co nejvíce možných modelů. Nejprve jsme se zaměřovali na hledání českých modelů. Ačkoliv se touto tematikou zabývali již dvě jiné práce, tak tato tematika není dostatečně prozkoumaná. Problémem bude nedostatek českých datasetů (podrobněji popsáno v kapitole 4). Obě dvě práce se zabývaly jednoduchými algoritmy. V první práci pan Červenec použil algoritmus podpůrných vektorů (SVM)[12]. Jeho výsledky se pohybovaly okolo 87% pro tři emoční třídy pozitivní, negativní a neutrální. V druhé práci pan Bilík vymyslel svůj algoritmus, který na základě emočně zabarvených slov a tokenizací jednotlivých slov vypočítával emoční zabarvení. Ačkoliv byl jeho algoritmus více propracovaný, jeho výsledky byly podstatně horší a dostal se na zhruba na 50% . Autor přikládá tento výsledek nedostatku seznamu slov s emočním zabarvením. [13].

Při hledání anglických modelů na detekci emocí v textu jsme se setkali s podobným problémem. Ačkoliv datasetů pro anglický jazyk je více. Výzkum v tomto odvětví není uveřejněn. Pravděpodobným důvodem neuveřejnění těchto výzkumů je vysoká hodnota pro vlastníky těchto modelů. Využívají je k personalizaci reklam a odhadování kybernetických zločinů.

3.2 AutoTrain

AutoTrain je bezkódový nástroj pro trénování nejmodernějších modelů pro úlohy zpracování přirozeného jazyka (NLP), pro úlohy počítačového vidění, (CV), pro úlohy řeči a dokonce i pro úlohy v tabulkách. Je postaven na špičkových nástrojích, vyvinutých týmem Hugging Face a je navržen tak, aby se dal snadno používat. [14]. Konkrétní model, který jsme použili, byl natrénovaný autorem Rahul Mallahem z Národního technologického institutu Silchar v Indii [15].

3.2.1 Trénování

Informace o datasetu, na kterém byl tento model trénován.

- Emoce v originále: anger, boredom, empty, enthusiasm, fun, happiness, hate, love, neutral, relief, sadness, surprise, worry.
- Emoce: hněv, nuda, prázdný, nadšení, zábava, štěstí, nenávisť, láska, neutrální, úleva, smutek, překvapení, starost.
- Počet trénovacích dat: 31995.
- Počet validačních dat: 8005.

Jelikož dataset již není veřejně přístupný, nejsme si jisti, zda se trénovací data tohoto datasetu nepřekrývají s některými námi používanými datasety k testování [16].

Uvedené ověřovací metriky:

- Přesnost: 0,394
- Makropřesnost : 0,217
- Mikropřesnost: 0,394
- Vážená přesnost: 0,345

3.3 Emotion Detection by Lawal Alfeez

Tento model je doladěný DistilBERT base model (uncased), který byl vyvinut přímo pro to, aby byl dále doladován na konkrétní úkoly. Bohužel autor tohoto modelu nesdílí informaci, na jakých datech byl tento model doladován. Tím, že je to model od Google, předpokládáme, že použil autor dataset GoEmotions. [17]

3.3.1 DistilBERT

DistilBERT je menší a efektivnější verze modelu BERT (Bidirectional Encoder Representations from Transformers), která je navržena pro použití na zařízeních s omezenými výpočetními možnostmi. Přesto si udržuje vysokou účinnost při porozumění přirozenému jazyku. Toho dosahuje pomocí tzv. distilace znalostí během předtréninku, což zmenšuje velikost modelu o 40 % a zvyšuje rychlost odhadu o 60% ve srovnání s většími modely.

Model je předtrénován pomocí trojitě ztrátové funkce, která kombinuje ztrátu jazykového modelování, distilaci a ztrátu kosinové vzdálenosti. Tato trojitá ztrátová funkce umožňuje modelu využít induktivní zkreslení, která větší modely získaly během předtréninku. [18]

3.3.2 BERT

BERT (Bidirectional Encoder Representations from Transformers) je nedávná práce od výzkumníků z Google AI Language, která představila revoluční přístup k modelování jazyka. Klíčovou inovací je aplikace bidirekcionálního tréninku transformeru, což umožňuje modelu lépe porozumět kontextu a toku jazyka. Tím dosahuje špičkových výsledků v různých úlohách zpracování přirozeného jazyka. Nová technika zvaná Masked LM (MLM) umožňuje bidirekcionální trénink, což představuje zlepšení oproti předchozím přístupům, které trénovaly modely pouze jednosměrně.[19]

3.4 Emotion Detection by Andy Luan

Model Emotion Detection jsme našli na stránce HuggingFace. A pomocí zpětného hledání informací, jsme zjistili, že je založen na modelu Bloom 560.[20] Autor nesdílí informace, na jakém datasetu byl tento model doladován. Tudíž nevíme přesné informace.

3.4.1 Bloom

Model BLOOM je nová iniciativa, která má za cíl demokratizovat přístup k mocné technologii velkých jazykových modelů (LLMs). BLOOM je otevřeně dostupný jazykový model s 176 miliardami parametrů, který byl navržen a vybudován díky spolupráci stovek výzkumníků.[21] Model Bloom byl zveřejněn na BigScience workshopu. BigScience není konsorcium, ani oficiálně založená entita. Jedná se o otevřenou spolupráci, kterou spustily společnosti HuggingFace, GENCI a IDRIS, a je organizována jako výzkumná dílna.[22]

Jedná se o dekodér-only transformer jazykový model, který byl trénován na korpusu ROOTS, který zahrnuje stovky zdrojů v 46 přirozených a 13 programovacích jazycích (celkem 59). Zjišťujeme, že BLOOM dosahuje konkurenčně výkonných výsledků na široké škále testovacích úloh, s ještě silnějšími výsledky po podstoupení multitask prompted fine-tuning. Pro usnadnění budoucího výzkumu a aplikací s využitím LLMs byli veřejně zpřístupněny modely a kód pod licencí Responsible AI. [21]

3.5 ChatGPT 3.5 turbo

ChatGPT je chatbot provozovaný firmou OpenAI. Byl vyvinut pomocí zpětnovazebního učení z lidské vazby. Počáteční model byl natrénován pomocí doladění pod dohledem. Lidští trenéři umělé inteligenci poskytovali konverzace, ve kterých předstírali být jak uživatelem, tak asistentem umělé inteligence. [23]

Využili jsme ho k testování emocí pomocí vstupního textu. Zkoušeli jsme několik variant tohoto vstupního textu. Nakonec jsme zakončili na této formě:

```
You are a psychologist. Your task is to recognise an emotion from text.
Example Text: "I like you I love you."
Return:
[{'label': 'love', 'score': 0.86}, {'label': 'joy', 'score': 0.1106},
{'label': 'surprise', 'score': 0.0116}, {'label': 'sadness', 'score':
0.0108}, {'label': 'anger', 'score': 0.0064}, {'label': 'fear',
'score': 0.0001}]
```

Tento formát nám umožňuje jasně prezentovat vstupní text, spolu s přiřazenými emocemi a pravděpodobnostmi. Takto získané výsledky jsou důležité pro naši analýzu a poskytují užitečné informace o schopnosti modelu ChatGPT rozpoznávat emocionální výrazy v textu.

Musíme však pečlivě zvážit výpovědní hodnotu těchto pravděpodobností. ChatGPT je generativní model. Data, která poskytuje, nemají pevné empirické podklady.

3.6 Llama70D

Llama, což je zkratka pro „Large Language Model Meta AI“, představuje kolekci auto-regresivních velkých jazykových modelů (zkráceně LLM), které Meta AI začala vydávat od února 2023.

První verze LLaMA obsahuje čtyři různé velikosti modelů: 7, 13, 33 a 65 miliard parametrů. Vývojáři LLaMA oznámili, že model s 13 miliardami parametrů dosáhl výkonu, který ve většině benchmarků v oblasti přírodního jazyka předčil i mnohem větší model GPT-3 (s 175 miliardami parametrů). Navíc bylo prokázáno, že největší model konkuruje nejmodernějším modelům jako PaLM a Chinchilla [24].

Nedávná práce Hoffmanna et al. z roku 2022 [25] poukazuje na to, že pro daný výpočetní rozpočet nejsou největší modely vždy tím nejlepším řešením. Místo toho se ukazuje, že menší modely trénované na rozsáhlejších datech často dosahují lepších výkonů.

Tato zjištění naznačují, že velikost modelu není jediným důležitým faktorem pro dosažení vysokého výkonu v oblasti zpracování přírodního jazyka. Namísto toho je klíčové efektivní využití dostupných výpočetních prostředků a optimalizace procesu trénování. Menší modely, které jsou trénovány na širším spektru dat, mohou lépe zachytit různorodé jazykové vzory a kontexty, což vede k lepší generalizaci a výkonu v reálném světě.

Tento přístup je důležitý zejména v oblastech, kde jsou k dispozici omezené zdroje, jako je výpočetní výkon nebo množství dostupných dat pro trénování. Zjištění Hoffmanna [25], tak poskytují cenný vhled do optimalizace jazykových modelů a ukazují, že efektivní využití dostupných prostředků může být klíčem k dosažení vysokého výkonu v aplikacích umělé inteligence [26].

■ 3.6.1 Groq

K testování jsme využili produkt firmy Groq. Groq je americká firma zaměřená na umělou inteligenci, která vyvíjí speciální integrovaný obvod pro aplikace urychlující umělou inteligenci nazvaný Language Processing Unit (LPU) a přidružený hardware, který zvyšuje výkon inference u AI pracovních zátěží.

Groq se stal prvním poskytovatelem API, který překonal hranici 100 tokenů za sekundu při běhu parametrického modelu Llama2-70B od společnosti Meta .

Groq momentálně hostuje různé open-source velké jazykové modely běžící na svých LPUs s veřejným přístupem. Přístup k těmto demonstracím je dostupný prostřednictvím webových stránek společnosti Groq. Výkon LPU při běhu těchto open-source LLMs byl nezávisle otestován společností ArtificialAnalysis.ai ve srovnání s dalšími poskytovateli LLM. Naměřený výkon LPU je uveden v tabulce níže:

K testování jsme použili stejný prompt jako u ChatGPT 3.6.

Model Name	Tokens/second (T/s)	Latency (seconds)
Llama2-70B	253 T/s	0.3s
Mixtral	473 T/s	0.3s
Gemma	826 T/s	0.3s

Tabulka 3.1. Výkon jazykového zpracování jednotky (LPU) pro velké jazykové modely (LLM)

Kapitola 4

Datové zdroje

Při hledání dat k testování jsme zjistili, že datasety pro anglický jazyk jsou relativně rozšířené. Jejich hlavním problémem je, že jsou dost často ohodnoceny strojem, nikoliv lidmi. Tudíž se pravidelně zanáší špatná data a tím se ničí modely. V naší práci odkazujeme na obecně uznávaný dataset GoEmotions, který vznikl v Google Research Center. Tento dataset však nevyužíváme k testování, jelikož je často využíván jako trénovací data a nelze zaručit, že nedochází k překrývání s trénovacími soubory testovaných modelů.

Veřejně dostupný dataset pro texty v českém jazyce jsme našli pouze jeden a to z roku 2014. Je velice malý a zabývá se politickou debatou v komentářích zpravodajských webových serverů.

Dalším běžným problémem při vytváření datasetů je řídký počet emocí. Tento problém se často řeší zařazením emocí do širších kategorií. Kategorizace emocí je rozsáhlým tématem, které spadá do několika vědních oborů. V naší práci jsme se rozhodli pro použití kategorizačních pravidel podle Ph.D. Paula Ekmana, vektorovou metodu Circumplex a použití rozpoznávání sentimentu. Podrobnější informace o tomto přístupu jsou uvedeny v kapitole věnované emocím 2.1.

4.1 Český dataset

Jediný volně přístupný dataset se zabývá pouze zabarvením politických textů, bohužel třídí data jen na pozitivně a negativně zabarvené, nikoliv do emocí. Dataset vznikl lidským ohodnocením komentářů z webových stránek idnes.cz, nova.cz, ihned.cz a novinky.cz [13].

- Počet dat: 100.
- Počet emocí: 3
- Maximální délka trénovacích a testovacích datasetů: 1707.
- Kategorie emocí: pozitivní, negativní, nerozpoznatelné, neutrální.
- Rok vydání: 2014

emoční zbarvení	počet výskytů
pozitivní	15
negativní	75
neutrální	4
nerozpoznatelný	6

Tabulka 4.1. Tabulka emočních zbarvení.

4.2 Emotion Dataset for Emotion Recognition Tasks

Dataset vytvořená pomocí Twitter API. Emoce byly přiděleny dle hashtagů jednotlivých tweetů a následně otestovány modely na detekci emocí. [27]

- Počet dat: 2000.
- Počet emocí: 6.
- Maximální délka trénovacích a testovacích datasetů: 296.
- Kategorie emocí: hněv, strach, radost, láska, smutek a překvapení.
- Kategorie emocí v originále: anger, fear, joy, love, sadness and surprise.
- Rok vydání: 2018

emoce	počet výskytů
sadness	581
joy	695
fear	224
anger	275
love	159
surprise	66

Tabulka 4.2. Tabulka emocí a jejich výskytů v datasetu Emotion Dataset for Emotion Recognition Tasks.

emoce	počet výskytů
sadness	581
joy	854
fear	224
anger	275
surprise	66

Tabulka 4.3. Tabulka výskytu emocí převedených do testovaných emocí v datasetu Emotion Dataset for Emotion Recognition Tasks.

4.3 Dataset Emotion Detection from Text

Data jsou sbírkou tweetů anotovaných emocemi za nimi. Datová sada je ručně anotována lidskými přispěvateli.

- Počet dat: 39827.
- Počet emocí: 13.
- Maximální délka trénovacích a testovacích datasetů: 167.
- Kategorie emocí: prázdný, smutek, nadšení, neutrální, starost, překvapení, láska, zábava, nenávisť, štěstí, nuda, úleva, hněv.
- Kategorie emocí v originále: empty, sadness, enthusiasm, neutral, worry, surprise, love, fun, hate, happiness, boredom, relief, anger.
- Rok vydání: 2021.

emoce	počet výskytů
empty	827
sadness	5165
enthusiasm	759
neutral	8638
worry	8459
surprise	2187
love	3842
fun	1776
hate	1323
happiness	5209
boredom	179
relief	1526
anger	110

Tabulka 4.4. Tabulka emocí a jejich výskytů v datasetu Emotion Detection from Text.

emoce	počet výskytů
neutral	9465
sadness	5344
joy	13112
fear	8459
anger	1433
surprise	2187

Tabulka 4.5. Tabulka výskytu emocí převedených do testovaných emocí pro dataset Emotion Detection from Text.

4.4 Dataset GoEmotions

Dataset vyvinutý Google. Největší manuálně ohodnocený dataset komentářů ze stránky Reddit. Rozlišuje velice jemné změny v emocích. Vysokou kvalitu anotací prokazuje prostřednictvím analýzy hlavních konzervovaných komponent.[28]

Tento dataset zmiňujeme, protože je obecně uznávaný. Při našem testování modelů jsme ho nevyužili, protože většina modelů je na něm trénovaná a výsledky by neměly žádnou vypovídající hodnotu.

- Počet dat: 58 009.
- Počet emocí: 27 + Neutrální.
- Maximální délka trénovacích a testovacích datasetů: 30.
- Kategorie emocí: obdiv, pobavení, hněv, mrzutost, souhlas, péče, zmatek, zvědavost, touha, zklamání, nesouhlas, znechucení, rozpaky, vzrušení, strach, vděčnost, smutek, radost, láska, nervozita, optimismus, hrdost, uvědomění, úleva, výčitky svědomí, smutek, překvapení.
- Kategorie emocí v originále: admiration, amusement, anger, annoyance, approval, care, confusion, curiosity, desire, disappointment, disapproval, disgust, embarrassment, excitement, fear, gratitude, sadness, flow, joy, love, nervousness, optimism, pride, awareness, relief, remorse, sadness, surprise.
- Rok vydání: 2020

Kapitola 5

Testování a implementace

5.1 Získávání dat

K získávání dat jsme využili 3 různé způsoby přístupu k modelům. U modelů, které byly na stránce HuggingFace, jsme použili interference API od HuggingFace. U modelu Llama jsme využili zprostředkovatele firmu Groq a ChatGPT jsme využili OpenAI API. Všechny modely jsme testovali na 1000 vzorcích z datasetu Emotion Detection from Text 4.2 a na 1000 vzorcích Emotion Dataset for Emotion Recognition Tasks 4.3 .

5.1.1 HuggingFace

HuggingFace API je jednoduchý způsob pro sbírání dat. Jediným limitem tohoto prostředku je omezený počet requestů za hodinu, konkrétně 300. Tudíž jsme sbírali data iterativně tři krát po 300 vzorcích a jednou po 100.

Do proměnné APIURL jsme vložili odkaz na testovaný model. Následně jsme vytvořili funkci query, která vrací výsledek v typu json.

```
APIURL = "https://api-inference.huggingface.co/models/rahulmallah/autotrain-emotion-detection-1366352626"
headers = {"Authorization": "Bearer_XXXXXXXXXXXX"}

def query(payload):
    response = requests.post(APIURL, headers=headers, json=payload)
    return response.json()
```

Zde je příklad výsledku pro text „*im feeling rather rotten so im not very ambitious right now*“. V příkladu vidíme, že si je model na 99,63% jistý, že je to smutný text. Nabízí i jiné emoce jako například překvapení, strach, zlobu, lásku a radost.

```
[[{'label': 'sadness', 'score': 0.9963397979736328}, {'label': 'surprise', 'score': 0.0013880676124244928}, {'label': 'fear', 'score': 0.0011507068993523717}, {'label': 'anger', 'score': 0.0005524386069737375}, {'label': 'love', 'score': 0.0003328618477098644}, {'label': 'joy', 'score': 0.00023615283134859055}]]
```

U modelu Emotion Detection by Andy Luan jsme museli použít přetypování výsledků na emoce. Zde je knihovna, kterou jsme použili a následný kód k přetypování emocí.

```
labels = {
    "LABEL_0": "sadness",
    "LABEL_1": "anger",
    "LABEL_2": "love",
    "LABEL_3": "surprise",
    "LABEL_4": "fear",
```

```
"LABEL_5": "joy"
}
```

```
for line in returnMat:
    for t in line:
        for emotion in t:
            for label in labels:
                if(emotion['label'] == label):
                    emotion['label'] = labels[label]
```

5.1.2 ChatGPT

U ChatGPT je dobré si předem vyzkoušet různé prompty. My jsme je zkoušeli v OpenAI playground, který nám následně vygeneroval kód k použití do API. U vytváření promptu je důležité se zamýšlet nad počtem tokenů, které spotřebuje daná prompta, protože se za to platí a v dalším vývoji je důležité minimalizovat cenu.

```
message = [{
    "role": "system",
    "content": "You are a psychologist. Your task is to recognise an
    emotion from text. You can choose from this emotions: " +
    emotions + ". Example\nText: \"I like you I love you.\"\n
    Return it in this format: \"{'label': 'love', 'score': 0.86},
    {'label': 'joy', 'score': 0.1106}, {'label': 'surprise', 'score':
    0.0116}, {'label': 'sadness', 'score': 0.0108}, {'label': 'anger',
    'score': 0.0064}, {'label': 'fear', 'score': 0.0001}\"\n"
}]
```

U ChatGPT bylo výhodou, že jsme mohli spustit kód na všechny texty zároveň. Nemuseli jsme to dělit do jednotlivých částí.

```
responses = []
for i in range(1,1001):
    message[1] = {"role": "user", "content": texts[i]}

    response = openai.chat.completions.create(
        model="gpt-3.5-turbo",
        messages=message,
        temperature=1,
        max_tokens=256,
        top_p=1,
        frequency_penalty=0,
        presence_penalty=0
    )
    responses.append((response.choices[0].message.content, emotions[i]))
```

Výstup pro text „*im feeling rather rotten so im not very ambitious right now*“ vypadá takto:

```
"{'label': 'sadness', 'score': 0.85}, {'label': 'worry', 'score': 0.12},
{'label': 'relief', 'score': 0.025}, {'label': 'empty', 'score': 0.015},
{'label': 'neutral', 'score': 0.01}, {'label': 'anger', 'score': 0.005},
{'label': 'boredom', 'score': 0.005}, {'label': 'hate', 'score': 0.005},
```



```
{'label': 'fun', 'score': 0.002}, {'label': 'love', 'score': 0.002},
{'label': 'enthusiasm', 'score': 0.001}, {'label': 'happiness', 'score':
0.001}, {'label': 'surprise', 'score': 0.001}]"
```

Můžeme vidět, že ChatGPT model označil správně emoci, ale s menší jistotou (85%) než předchozí model. Přidal mnohem více různých emocí, které v datasetu dokonce ani nejsou, takže se nedržel přímo instrukcí. Skóre zaokrouhluje na tisíce, což pro naše použití plně stačí. Skóre emocí stejně není velmi podložené, jak jsme psali v kapitole o tomto modelu 3.5.

5.1.3 Groq

Groq je v betaverzi bezplatná služba, která dává možnost přes API, které je hodně podobné ChatGPT API, spouštět různé modely, které jsou veřejně přístupné. Zde testujeme model Llama 70B.

```
client = Groq(
    api_key=apikey,
)
message = [{
    "role": "system",
    "content": "You are a psychologist. Your task is to recognise an
emotion from text. You can choose from this emotions: " +
    emotion_czech + ". Example\nText: \"I like you I love you.\"\n
Return it in this format: \"[{ 'label': 'love', 'score': 0.86},
{ 'label': 'joy', 'score': 0.1106}, { 'label': 'surprise', 'score':
0.0116}, { 'label': 'sadness', 'score': 0.0108}, { 'label': 'anger',
'score': 0.0064}, { 'label': 'fear', 'score': 0.0001}]\n"
}]
for i in range(0, len(emotions)):
    message[1] = {"role": "user", "content": texts[i]}

    response = client.chat.completions.create(
        messages= message,
        model="llama3-70b-8192",
        temperature=1,
        max_tokens=1024,
        top_p=1,
        stop=None,
    )
    responses.append((response.choices[0].message.content, emotions[i]))
```

Výstup pro text „*im feeling rather rotten so im not very ambitious right now*“ vypadá takto:

```
[{"label": "sadness", "score": 0.8173828125}, {"label": "anger",
"score": 0.18080578744411469}, {"label": "joy", "score":
0.0015524784103035927}, {"label": "fear", "score":
0.00021123634360264987}, {"label": "love", "score":
4.7431840357603505e-05}, {"label": "surprise", "score":
2.0087388463707612e-07}], [{"label": "sadness", "score":
0.48252853751182556}, {"label": "surprise", "score":
0.3269146680831909}, {"label": "anger", "score": 0.17156723141670227},
```

```

{"label": "fear", "score": 0.011996968649327755}, {"label": "joy",
"score": 0.0067683979868888855}, {"label": "love", "score":
0.00022419326705858111}]]

```

Můžeme vidět, že je má jisté skóre „sadness“, stejně jako ChatGPT. Má veliký rozptyl emocí, vyjmenoval všechny zadané emoce, které měl v promptě. Nezaokrouhluje skóre jako ChatGPT, ale stejně jako ChatGPT je toto skóre nepodložené.

5.1.4 Získávání českých dat

Jedinou českou sadu, kterou jsme našli, jsme testovali na modelech Llama 70D a ChatGPT turbo. Ostatní modely nerozumí českému jazyku a tudíž jsme je k testování nevyužili.

Problémem českých dat bylo, že mají mnohem méně kategorií než data anglická. Takže jsme měnili promptu.

```

[{"
  "role": "system",
  "content": "You are a psychologist. Your task is to recognise an
emotion from text. You can choose from this emotions: Neutral,
Negative, Positive, Undetectable. Example \nText: \"Miluji tě
strašně moc!\" \nReturn it in this format: \"[{'label': 'Positive',
'score': 0.97}, {'label': 'Undetectable', 'score': 0.1106},
{'label': 'Negative', 'score': 0.0016}, ]\" \n"
}]

```

Přesto, že jsme změnili promptu, tak model Llama 70D měl problémy dodržovat zvolený formát. Zároveň dělal hlubší analýzu textu než jsme potřebovali. Rozděloval to na jemnější emoce. Jak můžete vidět v této ukázce, kde popisoval text „*bezte radeji diskutovat pod SME, cesky soudni rad a zakony vam evidentne nic nerikaji*„.

```

`I recognize the emotion in this text as:\n\n"Negative"\n\nThe text
appears to be a statement in Czech, which translates to "I don't
want to discuss it under SME, the Czech judiciary and laws are clearly
not telling you anything." The tone of the text is dismissive and
slightly aggressive, indicating a negative emotional tone.`

```

Zároveň přeložil text do angličtiny. Je možné, že kdybychom přeložili promptu a emoční kategorie do českého jazyka, tak by se více držel zadání. Tento dataset jsme objevili až ke konci naší práce a už nezbyval čas dále testovat, proto jsme naše výsledky nechali na této promptě. A získali jsme emoce pomocí analýzy slovních řetězců, kde jsme hledali, jak často se emoce vyskytují. Emoci s maximálním výskytem jsme počítali jako emoci, kterou zvolil model.

```

def find_sentiment(txt):
    # Split the text into words
    text = txt
    words = text.replace('\n', ' ').replace('"', ' ').lower().split()

    # Define the words to find
    words_to_find = ['neutral', 'negative', 'positive', 'undetectable']

```

```

# Initialize a dictionary to store the counts
word_counts = {word: 0 for word in words_to_find}

# Iterate over the words in the text
for word in words:
    # Check if the word is in the list of words to find
    if word in words_to_find:
        # Increment the count for the word
        word_counts[word] += 1
return word_counts

```

5.2 Použité metody testování

Při hledání, jak porovnávat výsledky jednotlivých modelů, jsme došli k několika zádrhům. Díky tomu, že modely nevrací pouze jednu emoci, kterou považují za správnou, bylo nutné vymyslet sérii testů, podle kterých budeme hodnotit modely mezi sebou.

První funkcí, kterou jsme využili, je zda model našel emoci.

```

def test_if_found_emotion(data_unclear):
    # Ensure data_unclear has at least two elements
    if len(data_unclear) < 2:
        raise ValueError("Invalid input: data_unclear should contain
        at least two elements")

    data = eval(data_unclear[0])
    true_emotion = data_unclear[1]
    if not isinstance(data, list) or
    not all(isinstance(emotion, dict) for emotion in data):
        raise ValueError("Invalid input: data should be a list of
        dictionaries")

    for emotion in data:
        if emotion['label'] == true_emotion:
            return True, emotion['score']
    return False, None

```

Dále podobným způsobem jsme testovali, zda je emoce v prvních třech nejpravděpodobnějších emocích. Nebo zda je nejpravděpodobnější emoci.

Další sérií testů bylo, jak moc si je model jist, že tato emoce je ta správná. U těchto testů jsme udělali sérii jistější než 50%, 30% a 10%.

```

def test_better_than_half(data_unclear):
    # Ensure data_unclear has at least two elements
    if len(data_unclear) < 2:
        raise ValueError("Invalid input: data_unclear should contain
        at least two elements")

    data = eval(data_unclear[0])
    true_emotion = data_unclear[1]

    if not isinstance(data, list) or

```

```
not all(isinstance(emotion, dict) for emotion in data):
    raise ValueError("Invalid input: data should be a list of
    dictionaries")

for emotion in data:
    if emotion['label'] == true_emotion:
        if emotion['score'] > 0.5:
            return True, emotion['score']
return False, None
```

Problémem tohoto testu je, že modely nejsou konzistentní v hodnocení skóre. A tak bereme toto hodnocení pouze jako doplňující, nikoliv závazné.

Kapitola 6

Výsledky

Tato kapitola se zaměřuje na prezentaci a analýzu výsledků testování modelů pro detekci emocí z psaného textu. Výsledky byly získány pomocí několika různých modelů, které byly testovány na českých a anglických datasetech. Hlavními cíli této kapitoly jsou porovnat výkonnost jednotlivých modelů, analyzovat matice záměn a porovnat různé metody kategorizace emocí. Tato kapitola poskytuje důkladnou analýzu výkonnosti modelů pro detekci emocí, přičemž zvláštní pozornost je věnována rozdílům mezi jednotlivými modely a metodami kategorizace.

6.1 Matice záměn

Matice záměn poskytují podrobný pohled na to, jak dobře jednotlivé modely rozpoznávají různé emoce. Pro každý model byla vytvořena matice záměn, která ukazuje, jak často byly různé emoce správně nebo chybně identifikovány. Tato analýza pomáhá identifikovat, které emoce jsou pro modely nejobtížnější k rozpoznání a kde dochází k nejčastějším chybám.

6.1.1 Porovnání výsledků českého datasetu

Matice záměny pro model ChatGPT 6.2 na českých datech ukazuje, že model dosahuje 68% přesnosti při klasifikaci negativních sentimentů. Nicméně 32% těchto případů klasifikuje jako neutrální. U neutrálních sentimentů dosahuje model přesnosti 67%, ale 33% těchto případů zaměňuje za negativní. Při klasifikaci pozitivních sentimentů model dosahuje také 67% přesnosti, zatímco zbytek (33%) je zaměněn za neutrální. Model tedy vykazuje silnou schopnost rozpoznávat pozitivní a negativní sentimenty, ale má tendenci zaměňovat neutrální sentimenty za negativní. Další zajímavostí je, že model ChatGPT vůbec neklasifikoval data jako „Undetectable“. Celkově má model ChatGPT úspěšnost 77% 6.1.

Matice záměny pro model Llama 6.1 na českých datech ukazuje, že tento model dosahuje také 68% přesnosti při klasifikaci negativních sentimentů, přičemž 31% těchto případů klasifikuje jako neutrální a 1% jako pozitivní. U neutrálních sentimentů dosahuje model vyšší přesnosti 75%, ale 25% těchto případů zaměňuje za negativní. Při klasifikaci pozitivních sentimentů model dosahuje 47% přesnosti, s 40% případů klasifikovaných jako neutrální a 13% jako negativní. Model má také problémy s klasifikací nedetekovatelných sentimentů, kde 67% případů zaměňuje za neutrální. Celkově má model Llama úspěšnost 65% 6.1.

Model	Correct
ChatGPT 3.5 turbo	77%
Llama 70B	65%


Tabulka 6.1. Úspěšnost modelů pro česká data.

Oba modely, ChatGPT a Llama, dosahují stejné úrovně přesnosti (68%) při klasifikaci negativních sentimentů, ale mají různé míry chybovosti. Model ChatGPT má tendenci zaměňovat negativní sentimenty za neutrální, zatímco model Llama kromě neutrálních sentimentů zaměňuje malou část i za pozitivní.


Při klasifikaci neutrálních sentimentů je model Llama přesnější (75%) ve srovnání s modelem ChatGPT (67%), avšak oba modely mají podobnou míru chybovosti, kdy zhruba čtvrtinu případů zaměňují za negativní.

V případě pozitivních sentimentů vykazuje model ChatGPT vyšší přesnost (67%) ve srovnání s modelem Llama (47%). Model Llama má tendenci zaměňovat pozitivní sentimenty častěji za neutrální než model ChatGPT.

Celkově lze říci, že model ChatGPT poskytuje vyváženější a přesnější klasifikaci napříč všemi třemi kategoriemi sentimentů s celkovou úspěšností 77%, zatímco model Llama je silnější v rozpoznávání neutrálních sentimentů, ale méně přesný u pozitivních sentimentů, což vede k celkové úspěšnosti 65%. Oba modely vykazují určité slabiny při rozpoznávání sentimentů, které mohou být dále zlepšeny specifickým tréninkem a optimalizací pro česká data.



Obrázek 6.1. Matice záměn pro model Llama 70D na českých datech.



Obrázek 6.2. Matice záměn pro model ChatGPT 3.5 turbo na českých datech.


6.1.2 Porovnání v rámci kategorizace Circumplex

Matice záměny pro model Llama 70D 6.3 ukazuje, že tento model dosahuje nejvyšší přesnosti při klasifikaci emocí s vysokou aktivací a negativní valencí (High-A, Neg-V), kde správně klasifikuje 71% případů. Model také vykazuje slušný výkon při klasifikaci emocí s vysokou aktivací a pozitivní valencí (High-A, Pos-V) s přesností 67% a emocí s nízkou aktivací a negativní valencí (Low-A, Neg-V) s přesností 54%. Avšak model Llama 70D má tendenci zaměňovat emoce mezi sebou, zejména High-A, Neg-V a Low-A, Neg-V, což ukazuje na určitou míru zmatení mezi těmito kategoriemi.


Matice záměny pro model ChatGPT 6.4 ukazuje, že tento model má vysokou přesnost při klasifikaci emocí s vysokou aktivací a pozitivní valencí (High-A, Pos-V) s přesností 64% a emocí s nízkou aktivací a negativní valencí (Low-A, Neg-V) s přesností 59%. Nicméně, model často zaměňuje emoce s vysokou aktivací a negativní valencí (High-A, Neg-V), kde správně klasifikuje pouze 54% případů, zatímco 25% případů klasifikuje jako Low-A, Neg-V.

Matice záměny pro model Andy Luan 6.5 ukazuje, že tento model dosahuje nejvyšší přesnosti při klasifikaci emocí s vysokou aktivací a pozitivní valencí (High-A, Pos-V) s přesností 76% a neutrálních emocí (Neutral) s přesností 62%. Avšak model má značné problémy s klasifikací emocí s vysokou aktivací a negativní valencí (High-A, Neg-V), kde správně klasifikuje pouze 42% případů a 32% případů klasifikuje jako High-A, Pos-V.


Mahalan 6.6 ukazuje, že tento model exceluje při klasifikaci emocí s vysokou aktivací a pozitivní valencí (High-A, Pos-V) s přesností 68% a emocí označených jako „None“ s přesností 63%. Nicméně, model má výrazné slabiny při klasifikaci emocí s vysokou aktivací a negativní valencí (High-A, Neg-V), kde správně klasifikuje pouze 27% případů a většinu ostatních případů zaměňuje za „Neutral“ nebo „None“.



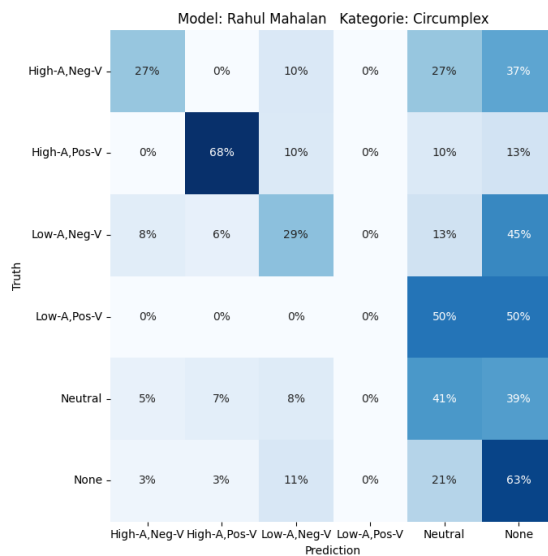
Obrázek 6.3. Matice záměn pro model Llama 70D, kategorizován dle modelu circumplex.



Obrázek 6.4. Matice záměn pro model ChatGPT 3.5 turbo kategorizován dle modelu circumplex.



Obrázek 6.5. Matice záměn pro model Andy Luan kategorizován dle Circumplex modelu.



Obrázek 6.6. Matice záměn pro model Rahul Mahalan, kategorizace: Circumplex.

Celkově lze říci, že modely Llama a ChatGPT poskytují vyváženější výsledky a méně výrazné chyby v klasifikaci, což je činí vhodnějšími pro úkoly, kde je důležitá konzistence a přesnost napříč různými emocionálními kategoriemi. Modely Andy Luan a Rahul Mahalan vykazují silné výsledky v určitých kategoriích emocí, ale mají výrazné slabiny v jiných, což ovlivňuje jejich celkovou výkonnost. Tyto rozdíly mezi modely podtrhují důležitost výběru vhodného modelu pro specifické úkoly rozpoznávání emocí a ukazují, že neexistuje univerzální řešení, které by vyhovovalo všem potřebám.


6.1.3 Porovnání v rámci kategorizace dle Ekmana

Porovnání matic záměn v rámci Ekmana nám rozlišuje jednotlivé kategorie už do představitelných emocí. Modely se značně liší v přesnosti klasifikace jednotlivých emocí. Model Llama 6.9 má nejvyšší úspěšnost při rozpoznávání „Anger“ a „Joy“, zatímco model Rahul Mahalan 6.8 exceluje v rozpoznávání „Fear“ a „Neutral“. Model Andy Luan 6.7 má vysokou úspěšnost při rozpoznávání „Joy“ a „Neutral“, a ChatGPT 6.10 dosahuje vysoké přesnosti při rozpoznávání „Anger“ a „Sadness“.


Všechny modely vykazují tendenci k zaměňování některých emocí. Například, model Llama často zaměňuje „Fear“ za „Sadness“, model Rahul Mahalan má tendenci zaměňovat „Anger“ za „Fear“ a „Neutral“, model Andy Luan často zaměňuje „Surprise“ za „Fear“, a model ChatGPT má tendenci zaměňovat „Fear“ a „Sadness“.

U modelu Andy Luan vidíme, že neklasifikoval nic jako „neutral“ a to mu zanáší chybu, jelikož data v sobě měla texty, které nebyly detekovatelné, ale model Andy Luan nemá klasifikační kategorii. Stejně tak můžeme vidět u modelu Rahul Malah stejnou chybu pro emoci „Suprise“, ačkoliv tento model umí klasifikovat tuto emoci. Narozdíl od těchto modelů, je vidět, že Velké jazykové modely Llama 70D a Chat GPT 3.5 turbo používali stejné emoce jaké měli datasety a tudíž jsou jejich data více pravidelně rozprostřená.


Většina modelů má problém s vyvážeností při rozpoznávání méně častých emocí. Například, model Llama nedokáže dobře klasifikovat „Disgust“, model Rahul Mahalan má nízkou přesnost při klasifikaci „Joy“, model Andy Luan má nízkou přesnost při klasifikaci „Disgust“, a model ChatGPT má nízkou přesnost při klasifikaci „Disgust“ a „Surprise“.




Obrázek 6.7. Matice záměn pro model Andy Luan, kategorizován dle Ekmana.



Obrázek 6.8. Matice záměn pro model Rahul Mahalan kategorizován dle Ekmana.



Obrázek 6.9. Matice záměn pro model Llama 70D kategorizován dle Ekmana.




Obrázek 6.10. Matice záměn pro model ChatGPT 3.5 turbo kategorizován dle Ekmana.


6.1.4 Porovnání v rámci kategorizace do sentimentů

Model Llama 6.13 dosahuje vysoké úspěšnosti při rozpoznávání negativních sentimentů, správně klasifikuje 76% těchto případů. Při identifikaci pozitivních sentimentů je jeho přesnost 68%. Model však často zaměňuje nedetekovatelné sentimenty za negativní, což ukazuje na některé slabiny v rozpoznávání méně výrazných sentimentů.

ChatGPT 6.14 vyniká zejména v klasifikaci negativních sentimentů s přesností 80%. Pozitivní sentimenty rozpoznává správně v 67% případů. Slabinou modelu je jeho tendence klasifikovat nedetekovatelné sentimenty jako negativní (55%) nebo pozitivní (25%), což naznačuje prostor pro vylepšení v rozlišení mezi těmito třemi kategoriemi.

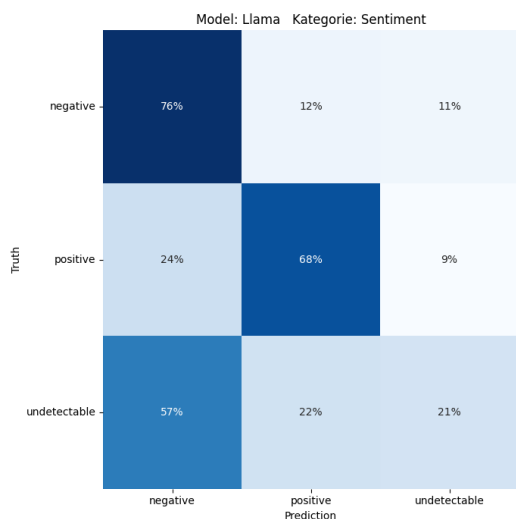


Obrázek 6.11. Matice záměn pro model Andy Luan kategorizován do sentimentů




Obrázek 6.12. Matice záměn pro model Rahul Mahalan kategorizován do sentimentů.

Model Andy Luan 6.11 vykazuje nejlepší výsledky při klasifikaci pozitivních sentimentů s přesností 74%. Při rozpoznávání negativních sentimentů dosahuje přesnosti



Obrázek 6.13. Matice záměn pro model Llama 70D kategorizován do sentimentů.



Obrázek 6.14. Matice záměn pro model ChatGPT 3.5 turbo kategorizován do sentimentů.

53%, přičemž značná část těchto případů (42%) je chybně klasifikována jako pozitivní. Rovněž je patrná vyšší míra záměny mezi nedetekovatelnými a pozitivními sentimenty (61%).

Model Rahul Mahalan 6.12 exceluje v rozpoznávání negativních sentimentů s přesností 76%. U pozitivních sentimentů je jeho přesnost nižší, dosahuje 57%, a v 27% případů jsou pozitivní sentimenty chybně klasifikovány jako negativní. Model také vykazuje značnou chybovost při klasifikaci nedetekovatelných sentimentů, kde je 57% případů zaměněno za negativní.

Celkově lze říci, že modely Llama a ChatGPT poskytují vyváženější výsledky a méně výrazné chyby v klasifikaci, zatímco modely Andy Luan a Rahul Mahalan vykazují silné výsledky v určitých kategoriích emocí, ale mají výrazné slabiny v jiných, což ovlivňuje jejich celkovou výkonnost. Což je pro následné použití v terapeutické aplikaci velice zásadní a znemožňuje to použití těchto modelů.


6.2 Porovnání kategorizačních metod

Ačkoliv to nebylo v zadání práce, velkou dobu jsme věnovali hledání a testování různých kategorizačních metod emocí, jak jste mohli vidět v sekci 6.1.


V začátcích této práce jsme nepoužívali žádné převody do jednotných kategorií, což se stalo následně problémem. Málokteré modely používají vždy stejné emoce jako datasety. Pokud je používají, je velká pravděpodobnost, že na těchto datasetech byly trénovány, protože je nedostatek kvalitně označených datasetů.

Při naší resherši jsme zjistili, že většina prací na toto téma používá buď základní emoce dle Ekmana, nebo nepoužívají emoce, ale pouze sentiment rozdělený na pozitivní, negativní a neutrální. Pro použití do terapeutické aplikace jsme chtěli, abychom znali emoci a nejenom sentiment. Pak jsme zjistili, že při rozdělení na emoce jsou modely dost nepřesné a dosahují úspěšnosti 40% až 60%. Výsledky modelů nebyly uspokojivé pro naši aplikaci a tudíž jsme přešli na hledání lepších variant.

Vycházeli jsme z matematického přístupu a předpokládali jsme, že bude možné vytvořit rozdělení emocí, které by kvantitativně určilo jejich vzájemnou vzdálenost. Při



Obrázek 6.15. Graf úspěšnosti v jednotlivých testech. Při převedení do kategorizace dle Ekmana.



Obrázek 6.16. Graf úspěšnosti v jednotlivých testech. Při převedení do kategorizace emocí dle Circumplex metody.

zkoumání jsme však zjistili, že humanitní vědy takto nepracují a že neexistuje přesné rozdělení emocí, které by určilo jejich vzdálenosti v multidimenzionálním prostoru. Na základě tohoto zjištění jsme se rozhodli testovat dvoudimenzionální model emocí, známý jako circumplex model, který klasifikuje emoce do čtyř kvadrantů na základě valence a aktivity.

Při testování tohoto modelu jsme zjistili, že se stále výsledky modelů pohybují v rozmezí úspěšnosti 40% až 60%, jak je ukázáno v grafu 6.16. Při tomto postupu byla ztracena informace o tom, o jakou emoci se jedná. Tudíž jsme přistoupili zpět k modelu základních emocí dle Ekmana, který má zhruba stejnou úspěšnost.


Stále jsme ale nechtěli přidat produkt, který má špatnou úspěšnost, do naší aplikace. Tudíž jsme přistoupili na použití převodu na sentiment, kde jsme získali, podstatně lepší úspěšnost, kterou můžete vidět v tabulce 6.2. V tabulce vidíme, že úspěšnost se pohybovala mezi 70% a 90%.

model	is found	the top one	more than 0.5
Autotrain	100,00%	91,92%	56,77%
Andy Luan	100,00%	67,79%	36,91%
ChatGPT 3.5 turbo	98,29%	89,54%	55,84%
Llama 70B	25,04%	86,64%	54,12%

Tabulka 6.2. Výsledky testů převedených na sentiment.

6.3 Obecné výsledky

Graf porovnání všech modelů v rámci jednotlivých šesti testů 5.2. Testy byly provedeny na datech z jednotlivých modelů. Na data pro provedení testů v grafu 6.17 nebyla použita žádná úprava kategorií emocí.



Obrázek 6.17. Graf úspěšnosti v jednotlivých testech na základních datech bez jakékoli kategorizace.

Model	Is found	top three	top one
Autotrain	100%	75%	37,77%
Lawal Alfeez	29,97%	28,62%	13,80%
Andy Luan	30,20%	19,13%	8,05%
ChatGPT 3.5 turbo	82,90%	68,01%	46,38%
Llama 70B	62,24%	51,25%	34,13%

Tabulka 6.3. Výsledky testů pro všechny modely.

Jak je vidět z tabulky 6.17 a grafu 6.3, model Autotrain od Rahul Malaha vždy najde emoci. Když se podíváme na to, zda je nalezená emoce ta správná, pohybuje se úspěšnost okolo 40%. Z toho plyne, že Autotrain exceluje v nalezení emocionálního výrazu, ale jeho úspěšnost při identifikaci nejvýraznějšího výrazu je nižší.

ChatGPT dosahuje v této kategorii lepších výsledků. Domníváme se, že to bude tím, že ChatGPT operoval se stejnými emocemi jako dané datasety. ChatGPT 3.5 turbo ukazuje konzistentně dobré výsledky a je nejúspěšnější při identifikaci nejvýraznějšího emocionálního výrazu.

Llama 70B má poměrně srovnatelnou úspěšnost jako model Autotrain, vykazuje průměrné výsledky v obou kategoriích.

Narozdíl od úspěchu velkých LLM modelů můžeme vidět, že modely Lawal Alfeez a Andy Luan, specificky trénované na tuto činnost, nedosahují dobrých výsledků. Lawal Alfeez a Andy Luan mají nejnižší úspěšnost v obou metrikách, což naznačuje jejich omezenou schopnost v úkolu rozpoznávání emocí.

V následujících dvou grafech vidíme porovnání po převodu do kategorií dle Ekmana a dle modelu Circumplex. Oba dva grafy neukazují výrazný rozdíl v změně úspěšnosti jednotlivých modelů. Circumplex má o pár procent lepší výsledky, ale obírá nás o emoci překvapení. Zároveň circumplex něříká konkrétní emoce, pouze pozici v grafu jak je ukázáno v sekci 6.2.

Z prezentovaných výsledků docházíme k závěru, že bychom měli v aplikaci použít dvoufázový systém zobrazování emocí. V první fázi bude terapeutovi zobrazeno, zda se

pacient cítí pozitivně nebo negativně. V druhé fázi bude klasifikována emoce pacienta, kterou si terapeut může zobrazit jen na vyžádání. Terapeut bude předem informován, že je to pouze orientační odhad emoce.

Kapitola 7

Závěr

Tato bakalářská práce se zaměřila na problematiku detekce emocí z psaného textu, což je oblast, která nabývá na významu s rozvojem digitální komunikace. V průběhu práce byly analyzovány různé metody a modely, které jsou schopné identifikovat a kategorizovat emoce vyjádřené v textu. Byly porovnány specializované modely, které jsou zaměřené na detekci emocí s významnými velkými jazykovými modely.

V teoretické části práce byla popsána základní teorie emocí, včetně modelů Paula Ekmana a Jamese Russella. Tyto modely poskytují rámec pro porozumění a kategorizaci emocí, což je klíčové pro efektivní detekci emocí v textu. Následně byly prozkoumány různé modely, jako je AutoTrain, Emotion Detection by Lawal Alfeez, modely od Andyho Luana, ChatGPT 3.5 turbo a Llama70D, a byly popsány jejich architektury a způsoby trénování.

Praktická část práce se zaměřila na implementaci a testování těchto modelů na různých datasetech. Výsledky ukázaly, že některé modely, zejména ChatGPT 3.5 turbo a Llama70D, dosahují lepších výsledků v rozpoznávání emocí než ostatní testované modely. Přestože každý model měl své silné a slabé stránky, velké jazykové modely se ukázaly jako robustnější a konzistentnější v detekci emocí.

Byly také identifikovány klíčové výzvy, které je třeba řešit při detekci emocí z textu, jako je nedostatek kvalitních datasetů, zvláště pro český jazyk, a variabilita v anotacích emocí. Tyto faktory mají významný vliv na výkonnost modelů a naznačují potřebu dalšího výzkumu a vývoje v této oblasti.

Celkově výsledky této práce přispívají k lepšímu porozumění metod detekce emocí z textu a ukazují, že použití velkých jazykových modelů může významně zlepšit přesnost a spolehlivost těchto systémů. Budoucí výzkum by se mohl zaměřit na zdokonalení existujících modelů, rozšíření dostupných datasetů a zkoumání nových přístupů k anotaci a kategorizaci emocí.

Literatura

- [1] Walter B. Cannon. The James-Lange Theory of Emotions: A Critical Examination and an Alternative Theory. *The American Journal of Psychology*. 1987.
- [2] M.B. Arnold. *Emotion and Personality: Psychological aspects*. Columbia University Press, 1960. ISBN 9780231089395.
<https://books.google.cz/books?id=G2srAAAAIAAJ>.
- [3] Yong Huang. A theory of emotion based on a universal model. *Humanities & Social Sciences Communications*. 2024, 11 (1), 362. Copyright - © The Author(s) 2024. This work is published under <http://creativecommons.org/licenses/by/4.0/> (the “License”). Notwithstanding the ProQuest Terms and Conditions, you may use this content in accordance with the terms of the License; Poslední aktualizace - 2024-03-05.
- [4] J.E. LeDoux. *The Emotional Brain: The Mysterious Underpinnings of Emotional Life*. Simon and Schuster, 1998. ISBN 9780684836591.
<https://books.google.cz/books?id=7EJN5I8sk2wC>.
- [5] S. Ivan. *Emoce a interpersonální vztahy*. Grada Publishing a.s., 2011. ISBN 9788024774527.
<https://books.google.cz/books?id=J8taAgAAQBAJ>.
- [6] Eduard H. Hovy. *What are Sentiment, Affect, and Emotion? Applying the Methodology of Michael Zock to Sentiment Analysis*. In: Nuria Gala, Reinhard Rapp a Gemma Bel-Enguix, eds. *Language Production, Cognition, and the Lexicon*. Cham: Springer International Publishing, 2015. 13–24. ISBN 978-3-319-08043-7.
https://doi.org/10.1007/978-3-319-08043-7_2.
- [7] Vanessa Van Edwards. The Definitive Guide to Reading Microexpressions (Facial Expressions). *Science Of People*. 2024.
- [8] Paul Ekman. Are There Basic Emotions? *Psychological Review*. 1992, 99 (3), 550–553. DOI 10.1037/0033-295x.99.3.550.
- [9] Ekman group. Atlas of Emotions.
- [10] JONATHAN POSNER, JAMES A. RUSSELL a BRADLEY S. PETERSON. The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology. *Development and Psychopathology*. 2005, 17 (3), 715–734. DOI 10.1017/S0954579405050340.
- [11] *Circumplex model of emotion.svg*.
https://commons.wikimedia.org/wiki/File:Circumplex_model_of_emotion.svg.
- [12] Bc. RADEK ČERVENEC. *ROZPOZNÁVÁNÍ EMOCÍ V ČESKY PSANÝCH TEXTECH*. 2011.
- [13] Jan Bilík. *Rozpoznání emocí v textu [online]*. 2014 [cit. 2024-05-03].
<https://theses.cz/id/315701/>. SUPERVISOR: RNDr. Zuzana Nevěřilová, Ph.D..

- [14] R. Page. Hugging Face Autotrain. 2024. DOI <https://doi.org/10.59350/7p1n4-wdv84>.
- [15] Rahul Mallah. *Autotrain emotion detection*. <https://huggingface.co/rahulmallah/autotrain-emotion-detection-1366352626>.
- [16] Rahul Mallah. *Autotrain emotion detection Dataset*. <https://huggingface.co/datasets/rahulmallah/autotrain-data-emotion-detection>.
- [17] Lawal Alfeez. *Emotion Detection*. https://huggingface.co/LawalAlfeez/emotion_detection.
- [18] Victor Sanh, Lysandre Debut, Julien Chaumond a Thomas Wolf. *DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter*. 2020.
- [19] Rani Horev. BERT Explained: State of the art language model for NLP. *Towards Data Science*. 2018.
- [20] Andy Luan. *emotion-detection*. <https://huggingface.co/andyluan/emotion-detection>.
- [21] BigScience Workshop: Teven Le Scao, Angela Fan a Christopher Akiki et al.. *BLOOM: A 176B-Parameter Open-Access Multilingual Language Model*. 2023.
- [22] *A one-year long research workshop on large multilingual models and datasets*. <https://bigscience.huggingface.co>.
- [23] OpenAI. *ChatGPT Research*. <https://openai.com/index/chatgpt>.
- [24] Wikipedia contributors. *LLaMA — Wikipedia, The Free Encyclopedia*. 2024. <https://en.wikipedia.org/w/index.php?title=LLaMA&oldid=1220833602>. [Online; accessed 8-May-2024].
- [25] Jordan Hoffmann, Sebastian Borgeaud, Arthur Mensch, Elena Buchatskaya, Trevor Cai, Eliza Rutherford, Diego de Las Casas, Lisa Anne Hendricks, Johannes Welbl, Aidan Clark, Tom Hennigan, Eric Noland, Katie Millican, George van den Driessche, Bogdan Damoc, Aurelia Guy, Simon Osindero, Karen Simonyan, Erich Elsen, Jack W. Rae, Oriol Vinyals a Laurent Sifre. *Training Compute-Optimal Large Language Models*. 2022. <https://arxiv.org/abs/2203.15556>.
- [26] Hugo Touvron, Thibaut Lavril, Gautier Izacard, Xavier Martinet, Marie-Anne Lachaux, Timothée Lacroix, Baptiste Rozière, Naman Goyal, Eric Hambro, Faisal Azhar, Aurelien Rodriguez, Armand Joulin, Edouard Grave a Guillaume Lample. *LLaMA: Open and Efficient Foundation Language Models*. 2023.
- [27] Elvis Saravia, Hsien-Chi Toby Liu, Yen-Hao Huang, Junlin Wu a Yi-Shin Chen. *CARER: Contextualized Affect Representations for Emotion Recognition*. In: Ellen Riloff, David Chiang, Julia Hockenmaier a Jun'ichi Tsujii, eds. *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*. Brussels, Belgium: Association for Computational Linguistics, 2018. 3687–3697. <https://aclanthology.org/D18-1404>.
- [28] Dorottya Demszky, Dana Movshovitz-Attias, Jeongwoo Ko, Alan Cowen, Gaurav Nemade a Sujith Ravi. *GoEmotions: A Dataset of Fine-Grained Emotions*. In: *58th Annual Meeting of the Association for Computational Linguistics (ACL)*. 2020.

Příloha A

Zkratky a použité nástroje

A.1 Zkratky

NLP	Natural Language Processing (Zpracování přirozeného jazyka)
ChatGPT	Chat Generative Pre-trained Transformer
CV	Computer Vision (Počítačové vidění)
SVM	Support Vector Machine (Metoda podpůrných vektorů)
AutoTrain	Automated Training (Automatizované trénování)
DistilBERT	Distilled Bidirectional Encoder Representations from Transformers (Destilované obousměrné reprezentace kódovače z transformátorů)
BERT	Bidirectional Encoder Representations from Transformers (Obousměrné reprezentace kódovače z transformátorů)
LM	Language Model (Jazykový model)
MLM	Masked Language Model (Maskovaný jazykový model)
ROOTS	Reliable, Open, and Objective Text Source (Spolehlivý, otevřený a objektivní textový zdroj)
AI	Artificial Intelligence (Umělá inteligence)
LLM	Large Language Model (Velký jazykový model)
PaLM	Pathways Language Model
SME	Small and Medium-sized Enterprises (Malé a střední podniky)

A.2 Použité nástroje

Podle metodologického pokynu č.5/2023 byl použit následující software při vytváření této práce:

Google Colab	při komunikaci s Hugging Face API k získávání dat z modelů.
Overleaf	k korekci textu a psaní práce.
ChatGPT	k feedbacku práce a formulaci vět.
Hugging Face API	získávání dat z modelů.
Google Tabulky	tvorba grafů a tabulek.
Audplot	tvorba matic záměn jednotlivých modelů
PyCharm	využívané integrované vývojové prostředí správu souborů a reformátování kódu.